

Duty Cycle の AR モデル化に関する一検討

大川 航平[†] 岩田 大輝[†] 梅林 健太[†] Janne Lehtomäki^{††} Miguel López-Benítez^{†††}
Satya Joshi^{††}

[†] 東京農工大学大学院工学府電気電子工学専攻 〒184-8588 東京都小金井市中町 2-24-16

^{††} University of Oulu P. O. BOX 4500 FIN-90014, University of Oulu, Finland

^{†††} University of Liverpool Merseyside, L69 3GJ, United Kingdom

あらまし 動的な周波数共用では、周波数利用に関する統計情報の活用が有用とされている。本稿では、時間軸方向の周波数利用率に相当する Duty Cycle (DC) を予測するために自己回帰 (Auto-Regressive: AR) モデル化の検討を行う。観測された DC を従来の AR モデルで表現しようとする、従来の AR モデルでは表現が困難な挙動 (平均値の時間変動, 時間相関が低い時間帯の存在) が存在する。この問題に対して、本稿ではパラメータの異なる 2 つのモデルを使い分けることで適切な DC のモデル化を行う。具体的には、閾値処理を用いて DC の状態 (高い or 低い) を分類し、各状態に対して AR モデル化を行う。また、DC の観測期間を変化させた場合の提案 AR モデルの適合性についての検証を行った。2.4GHz 帯における無線 LAN の DC の実測値を用いた各 DC 時系列のモデル評価より、提案した DC 状態を考慮したモデルの妥当性と、DC の観測期間を長くするほど予測精度が改善されることが確認された。

キーワード コグニティブ無線, ダイナミックスペクトラムアクセス, スマートスペクトラムアクセス, 周波数利用率, 自己回帰モデル

A study on Auto-Regressive modeling of Duty Cycle

Kohei OKAWA[†], Hiroki IWATA[†], Kenta UMEBAYASHI[†], Janne LEHTOMÄKI^{††}, Miguel LÓPEZ-BENÍTEZ^{†††}, and Satya JOSHI^{††}

[†] Department of Electrical and Electronic Engineering, Tokyo University of Agriculture and Technology
2-24-16, Naka-cho, Koganei-shi, Tokyo, 184-8588 Japan

^{††} University of Oulu P. O. BOX 4500 FIN-90014, University of Oulu, Finland

^{†††} University of Liverpool Merseyside, L69 3GJ, United Kingdom

Abstract In dynamic spectrum sharing, statistical information in terms of spectrum usage is useful since it can enhance spectrum efficiency of the spectrum sharing. In this paper, we investigate AR (Auto-Regressive) modeling to predict DC (Duty Cycle) which is spectrum occupancy rate in time domain. Typical AR model based has two issues in the prediction: time-varying of statistics of DC and existence of time period with low-correlation. To overcome the issues, we propose a DC status based AR model in which two statuses (high DC and low DC) are considered. Specifically, the proposed model classifies the states of DC value (high or low) by threshold and two models are set under each status. We also consider an effect of observation time duration of DC estimation. Comprehensive spectrum measurements based numerical evaluations verified validity of the DC status based AR model.

Key words Cognitive radio, dynamic spectrum access, smart spectrum access, duty cycle, auto-regressive model.

1. はじめに

近年、第五世代移動通信システム (5th Generation: 5G) やモノのインターネット (Internet of Things: IoT) などの新たな無線通信技術の登場により、無線通信への需要が増している。

一方で、周波数はその多くが既に固定的かつ排他的に割り当てられており、新規無線システムに対して割り当て可能な周波数帯域が不足する周波数逼迫問題が発生している。しかし、割り当て済みの周波数は時間や場所によっては既存の一次利用者 (Primary User: PU) による周波数の利用率は高くなく、white

space と呼ばれる未使用の周波数帯域が存在することが知られている [1].

そこで周波数資源の不足解消および効率的な周波数利用を目的として、Dynamic Spectrum Access (DSA) が検討されている [2]. DSA は PU に割り当て済みでありながら時間的あるいは空間的に利用されていない周波数を、周波数が割り当てられていない新規の二次利用者 (Secondary User: SU) が二次利用する周波数共用技術である。DSA において、SU は PU の通信を妨害してはならないため、SU 周囲の PU の周波数利用状況を適切に把握する必要がある。

時間軸の周波数共用では、十分速くかつ高精度に周波数の利用状態を把握することが要求される。これには瞬時の周波数利用の有無を検出できる技術であるスペクトルセンシングが一般的に用いられる [3]. さらに SU が小型の無線端末である場合には低コストかつ低演算量な実装が要求され、これら全ての要求を同時に満たすことは困難である。

このような課題を解決するアプローチとして、図 1 に示すような 2 階層型の Smart Spectrum Access (SSA) と呼ばれる、PU の周波数利用に関する統計情報を活用した周波数共用技術が検討されている [4]. SSA の第 1 階層では PU と SU の周波数共用が行われる。第 2 階層では周波数利用観測システム (Spectrum Awareness System: SAS) が PU の周波数利用統計情報を取得し蓄積したデータを用いて学習を行う。学習結果をもとに SAS が予測を行う。SAS による PU の周波数利用統計情報の取得および提供により、SU の効率の良い周波数共用が実現できる。本稿では、周波数利用統計情報の一つである Duty Cycle (DC) のモデル化に着目する。DC は時間軸方向に対する周波数利用率に相当する。

これまでに、周波数利用観測に基づいた DC のモデル化手法がいくつか検討されている [5] [6] [7] [8]. サーベイ論文である [5] では、様々な DC のモデル化として確率的モデル化、マルコフモデルを活用したモデル化、そして線形回帰に基づくモデル化が検討されてきていることが紹介されている。[6] では混合ベータ分布を用いた DC の確率論的モデル化と時間軸の DC の変動を決定論的モデルでモデル化することが検討されている。[7] では DC が 1 日を周期とする周期変動をもつことを利用し、季節自己回帰和分移動平均 (Seasonal Auto-Regressive Integrated Moving Average: SARIMA) モデルに基づく時系列モデルを構築している。このような時間軸での DC の統計値の変化に対して [8] では短期間の DC の相関値に基づいて 2 つのモデルを活用した AR(Auto-Regressive) モデル化の検討が行われている。

本稿では、新たな DC の状態変化を考慮した AR モデル化の提案を行う。具体的には、提案 AR モデルは相関値ではなく DC の値そのものから DC 時系列モデルを使い分ける方法となる。これは、DC が低い値をとる傾向にある時間帯では時間相関が低いのに対し、比較的 DC が高い時間帯では時間相関が高いことを根拠としている [8]. DC はある観測期間より得ることから、DC 自体が確率過程となり、観測期間が短いほどその分散は大きくなる。このとき、観測期間がモデルによる DC の予

測精度に与える影響の検証も行い、その特徴を明らかにする。そして、2.4 GHz 帯の無線 LAN における周波数利用観測実験により本検討モデルの妥当性を示す。

本稿の構成は、2 章で周波数観測実験の諸元を述べ、3 章にて従来の AR モデルについて紹介した後、4 章では提案モデルとなる状態判定に基づく AR モデルを示す。5 章において提案モデルと各パラメータ設定について数値評価を行い、6 章で結論を述べる。

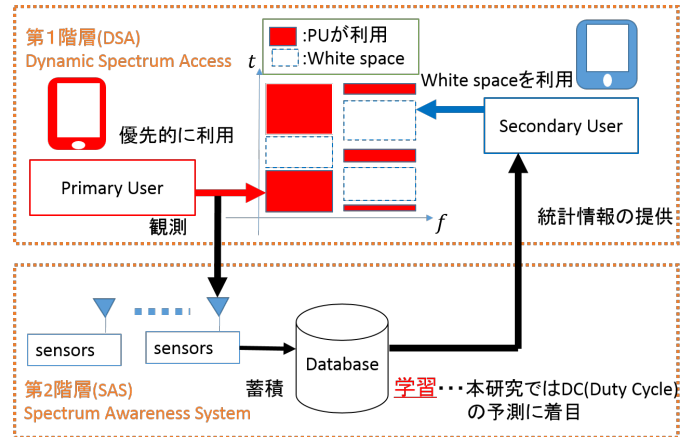


図 1 SSA

2. 周波数観測諸元

本稿では Wireless Local Area Network (無線 LAN) における DC の時系列モデル化について検討する。東京農工大学小金井キャンパス 5 号館 408 号室 (東経 139.5 度北緯 35.7 度) に設置した周波数利用観測システム (図 2) を用いて、図 3 に示す時間構成で周波数利用観測を行った。

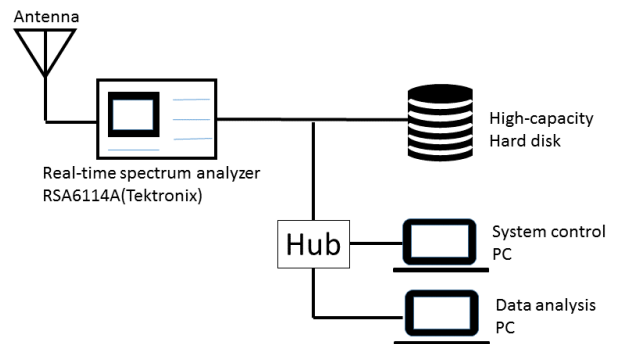


図 2 周波数観測システム

表 1 周波数利用観測諸元

観測場所	東京農工大学小金井キャンパス 5 号館 408 号室
観測日	2017/11/21, 22, 24, 27~30, 2017/12/1, 4~8, 12~14, 19~22, 26~29
観測中心周波数	2,437MHz
観測帯域	1.25MHz
連続観測期間	0.25 sec
観測周期	5 sec




図 3 各推定期間での DC の導出

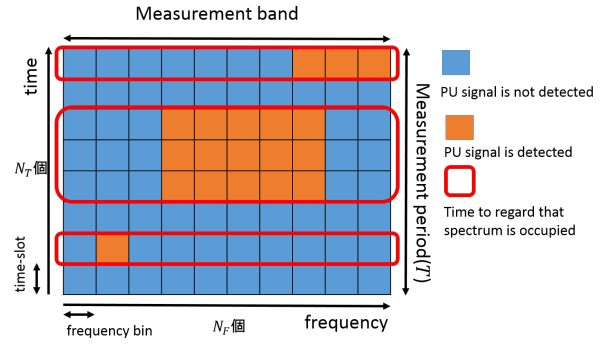


図 4 DC の計算方法

具体的には、連続観測期間 (Measurement period) $T = 0.25$ [sec], 観測周期 (Measurement cycle) $N = 5$ [sec] と設定した。観測日数 N_D は 24 日間とし、表 1 に示す観測諸言で周波数利用観測を実施した。

2.4GHz 帯無線 LAN アンテナ (NATEC 社 VA2409A) が接続されたリアルタイムスペクトラムアナライザ (Tektronix 社 RSA6114A) は、間欠なく連続的に T 秒間 IQ データを取得する。取得した IQ データは、ネットワークを介して大容量ハードディスク (High-capacity Hard disk) に保存される。この時、観測周期 N は IQ データ転送が完了するのに十分な時間長に設定する。

次にデータ解析用コンピュータ (Data analysis PC) により、蓄積された IQ データに対して Welch FFT (Fast Fourier Transform) に基づく電力検出と後処理によって周波数利用の検出を行う [9] [10]。連続観測期間 T は N_T 個のタイムスロットに分割される。そして、FFT サイズが N_F の Welch FFT を各タイムスロットに対して行い、パワースペクトルを推定する。この時、各タイムスロットに存在する周波数ビン数は N_F となる。周波数利用の検出は、 $N_T \times N_F$ から成るタイルのパワースペクトルに対する電力検出、および誤警報除去 [9]、信号領域推定 [10] に基づいて行われる。ここで、タイルとは 1 タイムスロット -1 周波数ビンで構成される領域を指す [10]。本稿では、タイムスロットサイズ = 512, FFT サイズ = 128, Welch FFT におけるオーバーラップ率 = 0.5 とする。これにより、 $N_T = 854$, $N_F = 128$ となる。電力検出に用いる閾値は、誤警報確率が 0.01 を満たすように設定を行う。また、所望の誤警報確率を満たす閾値を設定するためには、ノイズフロアの情報が必要となる。ノイズフロアレベルは時変であり、周波数依存性を持つことが知られている。そのため本研究ではノイズフロアの時変特性と周波数依存性がある中で高精度にノイズフロアを推定可能な MED-tED-mean 法 [11] を用いる。

電力検出及び誤警報除去、信号領域推定後の周波数利用の検出値は下記で与えられる。

$$D_{n_T, n_F} = \begin{cases} 1 & (\text{PU signal is detected}) \\ 0 & (\text{PU signal is not detected}) \end{cases} \quad (1)$$

最後に、得られた周波数利用の検出値を用いて DC を推定する。DC は $N = 5$ sec 毎に推定される。図 4 に、本稿で定義する DC の計算方法を示す。図 4 に示した周波数-時間の図は、

文献 [9] および [10] の手法を用いて得られる $N_T \times N_F$ の周波数利用検出結果の一例である。観測期間中の各タイムスロットにおいて、観測帯域のうち一箇所でも周波数利用が行われていると判定された場合、そのタイムスロットは周波数利用があるとみなす。観測期間中の周波数利用率を算出したものが DC の推定値となる。DC 観測の時間インデックスである m を用いて 5sec 毎の DC の推定値 $x[m]$ は次式で与えられる。

$$x[m] = \frac{1}{N_T} \sum_{n_T} \left(1 - \prod_{n_F} (1 - D_{n_T, n_F}) \right) \quad (2)$$

本稿では $x[m]$ を用いて導出した 5n 秒毎の DC の推定値 $x_n[m]$ の時系列モデル化について検討を行う。 $x_n[m_n]$ は $x[m]$ を n 個毎に平均化したものであり、次式で与えられる。

$$x_n[m_n] = \frac{1}{n} \sum_{k=0}^{n-1} x[m_n n + k] \quad (3)$$

最小推定期間を 5sec, $x_n[m_n]$ の 1 つの値の推定に用いる時間 5nsec を $x_n[m_n]$ の推定期間とする。

3. 従来 AR モデル

従来の AR モデル [12] を用いた DC の時系列モデルは以下の式で表される。

$$\hat{x}_n[m_n] = z + \sum_{i=1}^{p_n} a_n^i \{x_n[m_n - i] - z\} \quad (4)$$

z は学習により得られた DC の平均値であり時不変の値を用いる。 a_n^i は i 時点過去の DC 観測値に対する AR モデルの係数、 p_n は AR モデルの次数であり、それぞれ Yule-Walker 法と偏自己相関を用いて決定される。図 5 に観測実験により得られたデータを用いた場合の DC の偏自己相関を示す。ラグが 1 のときに比較的值が大きく、ラグが 2 以降では比較的小さい値を取っているため、従来 AR モデルの次数は $p_n = 1$ と設定する。

図 6 に実証実験により得られた DC の観測値と、従来の AR モデルによる DC 予測値を示す。DC が低い値の場合 (時間 13:01 以前)、観測された DC はパルス上にランダムに高くなる可能性があることが確認される。それに対して、予測値は、1 時点遅れてその挙動を模擬することで誤差を増やす要因となるこ




図5 DCの偏自己相関

とが確認される。また、DCが高い場合(時間13:01以降)、観測されたDCは急激に高くなり、高いDCを連続的に達成しているのに対して、予測DCはその最大値が0.6あたりで留まっていることが確認される。これも、誤差を増やす原因となる。

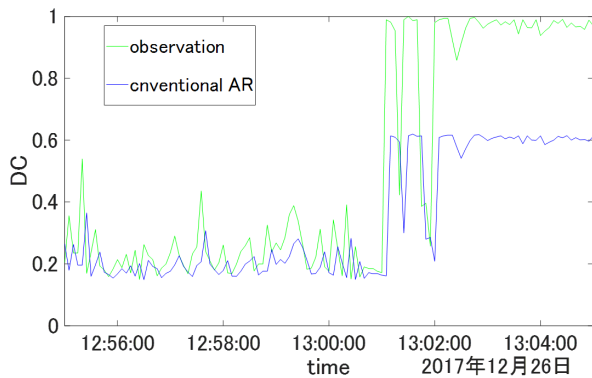


図6 従来ARモデルによる予測

4. 状態判定に基づくARモデル

4.1 概要

3章に示した理由から、提案するARモデルでは状態 S_1 (DCが相対的に高い場合)と状態 S_0 (DCが相対的に低い場合)において時系列モデルを以下のとおり使い分ける。

$$\hat{x}_n[m_n] = \begin{cases} z_n[m_n] + \sum_{i=1}^{p_n} a_n^i \{x_n[m_n - i] - z_n[m_n]\} & (S_n[m_n] = S_1) \\ z_n[m_n] & (S_n[m_n] = S_0) \end{cases} \quad (5)$$

$S_n(m_n)$ は時刻 $5m_n$ における状態を表す。 a_n^i は i 時点過去の観測値に対するARモデルの係数、 p_n はARモデルの次数である。これらは、状態 S_1 である時間帯のDCの学習データから推定する。 $z_n(m_n)$ はその時刻における q 時点前までのDCの平均値であり、時間により変動する。本稿では $q = 10$ とした。 $z_n(m_n)$ の式を以下に示す。

$$z_n(m_n) = \frac{1}{q} \sum_{i=1}^q x_n[m_n - i] \quad (6)$$

4.2 状態 $S_n(m_n)$ の判定方法

本モデルではDCを高い状態と低い状態に分けてモデル化を行うため、その状態判定が必要である。状態判定は以下のとおり行う。

$$S_n[m_n] = \begin{cases} S_1 & ((x_n[m_n - 1] > \eta) \& (x_n[m_n - 2] > \eta)) \\ S_0 & (\text{otherwise}) \end{cases} \quad (7)$$

すなわち、過去2時点の観測DCが閾値 η を超えたとき状態 S_1 、それ以外を状態 S_0 と判定する。DCが低い傾向にある時間帯において、突発的に1時点だけDCが高くなることしばしば発生する。この場合は、DCは低い状態に留まっていると判定をさせるために過去2時点のDC観測値を用いて上体判定を行う。

4.3 提案モデルのパラメータ(a_n, z_n)推定

ARモデルの次数は偏自己相関の値によって推定できることが知られている[12]。図7, 8はそれぞれ状態 S_0 、状態 S_1 における偏自己相関の値の例である。2通りの n の値に対して、それぞれ誤差を最小にする最適な閾値によって状態判定を行い、状態 S_0 、状態 S_1 それぞれの偏自己相関を導出した。状態 S_1 の偏自己相関の値は図8に示すように、全体としてラグが1のとき非常に大きい値をとっており、ラグが2以上では大きく落ち込み一転して小さい値をとっている。このことから状態 S_1 の場合は次数 p_n の値は1とした。状態 S_1 のAR係数 a_n^i はYule-Walker法により決定した。

対して、状態 S_0 の偏自己相関の値は図7に示すように、 $n = 1$ 、 $n = 10$ のときにはラグが大きくなるにつれてゆるやかに値が小さくなっている。 $n = 25$ の場合にはラグが1のときに非常に小さい値をとっており、状態 S_0 はARモデルによる予測に適していない。そのため、状態 S_0 ではARモデルは用いず、その時点での平均値の推定値 $z_n(m_n)$ のみで予測を行う。

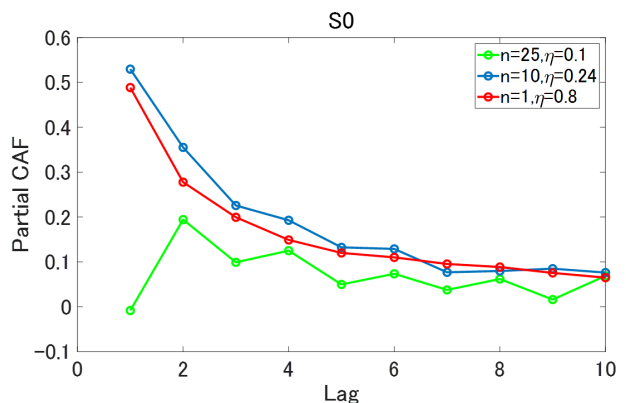


図7 状態 S_0 での偏自己相関

5. 数値評価

5.1 諸元

2.4 GHz 帯無線LANの実観測データを用いて、検討したDCのモデルを構築し評価を行う。予測誤差として(8)に示す二乗平均平方根誤差(Root Mean Square Error: RMSE)を用いる。




図 8 状態 S_1 での偏自己相関




図 10 各モデルの RMSE

$$\text{RMSE} = \sqrt{\mathbb{E} [\{\hat{x}_n(m_n) - x_n(m_n)\}^2]} \quad (8)$$

5.2 提案モデルと従来 AR モデルとの比較

$n = 1$ のときの提案モデル (two state based AR) による DC 予測値を図 9 に示す。DC が低い値のときには細かい振動に追従しすぎず、DC が高い値の時にはしっかりと追従できている。図 10 に n を横軸、予測誤差を縦軸にとったグラフを示す。two state based AR が式 (5) に示す提案モデル、conventional AR は一般的な AR モデル式 (4) を示しており、 $S_n=S_1$ は式 (5) において全ての DC を高いと判定するモデル、 $S_n=S_0$ は式 (5) において全ての DC を低い状態と判定するモデルである。推定期間 $5n\text{sec}$ が小さい $n = 1$ ときは AR モデルの誤差は比較的大きいのに対し、推定期間が大きい $tn = 20$ のときには $S_n=S_0$ が最も誤差が大きくなっている。このことから、推定期間が小さい場合は大きい場合と比べ、AR モデルによる予測を行うことが困難であると考えられる。10 以下の n に対して提案モデルは他のモデルに比べ予測誤差が最も小さくなっている。しかし、 n の値が 25 程度まで大きくなると、従来の AR モデルが最も誤差が小さい。これは推定期間が大きくなることにより、AR モデルによる予測の精度が向上していることに加え、提案モデルにおける平均値 $z_n(m_n)$ が参照している 10 時点と言う範囲が、推定期間が長くなるにつれ、絶対的に長くなってしまい、その時点での平均値としての役割を果たせなくなっていくためと考えられる。




図 9 状態判定に基づく AR モデルによる予測結果 ($n=1$)

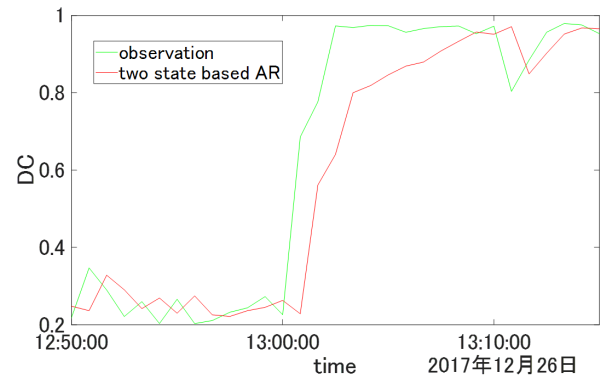


図 11 状態判定に基づく AR モデルによる予測結果 ($n=10$)

5.3 推定期間の評価

図 10 より、いずれのモデルに関しても、推定期間が大きい方が予測誤差の値が小さくなっている。推定期間が大きい方が全体として予測が容易になることがわかる。図 12 はパラメータ n を変化させたときの最も誤差が小さくなる最適な閾値の値を示している。このグラフから、推定期間を大きくすると、最適な閾値の値は小さくなることがわかる。これはつまり、推定期間が大きい方が AR モデルを使用できる値の範囲が広いことを意味する。




図 12 各推定期間に対する最適な閾値

5.4 閾値の評価

図 13, 図 14 に示すのは, それぞれの n の値における, 閾値の RMSE 特性である. 推定期間が大きくなるにつれて最小値をとる閾値が変化していく様子が確認できる. また, 推定期間が短い方が, 閾値を変化させたときに RMSE が比較的大きく変化する.




図 13 $n = 1$ のときの各閾値に対する誤差




図 14 $n = 10$ のときの各閾値に対する誤差

6. おわりに

本稿では PU の周波数利用統計情報である DC の値の高低により適切な時系列モデルが異なることに着目した DC の時系列モデルを提案した. 具体的には, DC を高い状態と低い状態に分類し, 各時間に対する平均の DC の変動を考慮した AR モデルによる時系列モデル化を行った. また, DC の観測期間が時系列モデルを用いた DC 予測に与える影響の評価も行った. 2.4 GHz 帯無線 LAN の周波数利用観測実験により得られた実観測データを用いて本検討モデルを構築し検証を行った結果, 比較的短い推定期間の場合において提案 AR モデルは従来の AR モデルに比べ高精度な予測が可能であることが明らかになった. また, 異なる推定期間に対する最適な状態判定のための閾値を導出し, それぞれの予測制度を評価した. AR モデルは推定期間が大きい程予測精度が良くなることを示した. また, 推定期間が大きくなると, 最適な閾値は小さくなることを示した.

謝 辞

本研究は, 日欧共同公募 H2020-EUJ-02-2018 (総務省) プロジ

エクト 5G-Enhance (No. 815056) 及び科研費 (JP18K04124, JP18KK0109) の助成を受けたものである.

文 献

- [1] D. Cabric, S. M. Mishra, and R. W. Brodersen, "Implementation issues in spectrum sensing for cognitive radios," *Conference Record of the Thirty-Eighth Asilomar Conference on Signals, Systems and Computers*, vol. 1, pp. 772–776, Nov. 2004.
- [2] S. Bhattarai, J. J. Park, B. Gao, K. Bian, and W. Lehr, "An overview of dynamic spectrum sharing: Ongoing initiatives, challenges, and a roadmap for future research," *IEEE Transactions on Cognitive Communications and Networking*, vol. 2, no. 2, pp. 110–128, June 2016.
- [3] S. Haykin, D. J. Thomson, and J. H. Reed, "Spectrum sensing for cognitive radio," *Proceedings of the IEEE*, vol. 97, no. 5, pp. 849–877, May 2009.
- [4] K. Umehayashi, S. Tiirro, and J. J. Lehtomäki, "Development of a measurement system for spectrum awareness," *1st International Conference on 5G for Ubiquitous Connectivity*, pp. 234–239, Nov. 2014.
- [5] Y. Chen and H. Oh, "A survey of measurement-based spectrum occupancy modeling for cognitive radios," *IEEE Communications Surveys Tutorials*, vol. 18, no. 1, pp. 848–859, Firstquarter 2016.
- [6] K. Umehayashi, M. Kobayashi, and M. López-Benítez, "Efficient time domain deterministic-stochastic model of spectrum usage," *IEEE Transactions on Wireless Communications*, vol. 17, no. 3, pp. 1518–1527, Mar. 2018.
- [7] Z. Wang and S. Salous, "Spectrum occupancy statistics and time series models for cognitive radio," *Journal of Signal Processing Systems*, vol. 62, no. issue2, pp. 144–155, Feb. 2011.
- [8] 長大樹, 梅林健太, 成枝秀介, and M. López-Benítez, "スマートスペクトラムアクセスのための duty cycle の時系列モデル化," *信学技報*, vol. 117, no. 457, SR2017-112, pp. 1–7, Feb. 2018.
- [9] R. Mizuchi, K. Umehayashi, J. J. Lehtomaki, and M. Lopez-Benitez, "A study on false alarm cancellation for spectrum usage measurements," *2017 IEEE Wireless Communications and Networking Conference Workshops (WCNCW)*, no. 2, pp. 1–6, Mar. 2017.
- [10] K. Umehayashi, K. Moriwaki, R. Mizuchi, H. Iwata, S. Tiirro, J. J. Lehtomäki, M. López-Benítez, and Y. Suzuki, "Simple primary user signal area estimation for spectrum measurement," *IEICE Transactions on Communications*, vol. E99.B, no. 2, pp. 523–532, 2016.
- [11] H. Iwata, K. Umehayashi, S. Tiirro, J. J. Lehtomäki, M. López-Benítez, and Y. Suzuki, "Welch fft segment size selection method for spectrum awareness system," *IEICE Transactions on Communications*, vol. E99.B, pp. 1813–1823, Aug. 2016.
- [12] J.D.Hamilton, "Time series analysis," *Princeton, NJ: Princeton Univ. Press*, 1994.